

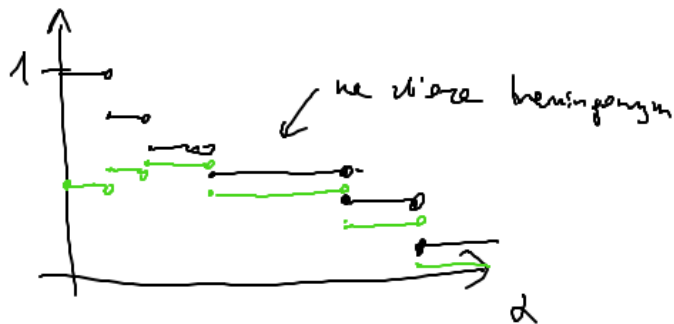
Drzewa decyzyjne



Pręcinanie - parametr d
 Jak wybrać d ?

1) Model błędności na zbiorze testowym

wynika wygląda tak:



→ nie wystarczy
 danych treningowych



2) Walidacja krzyżowa: dzielimy dane treningowe na K części: A_1, A_2, \dots, A_K

K -krotnie powtarzamy, dla $k=1, \dots, K$:
 Ustalmy d_0 .

- i) otrzymane drzewo dla danych treningowych bez A_k
- ii) pręcinamy je dla d_0 .
- iii) porównujemy na błędności na zbiorze A_k

} \Rightarrow wybieramy
 dane d_0
 i tworzymy drzewo

• Bootstrap aggregation (bagging)

Ogólna metoda, ale najczęściej używana do drzew.

1) Bieremy B zbiorów treningowych wielkości N każdy

2) Tworzymy model dla każdego ze zbiorów

3) Łączymy je w jeden model:

- bierzemy średnią dla regresji

- bierzemy „głosowanie” dla klasyfikacji



np. $N=1000$ elementów

losujemy 1000 razy
element ze zbioru

ad 1) Każdy ze zbiorów treningowych jest stworzony z oryginalnego zbioru poprzez

losowanie próbek ze zbioru N razy

(najczęściej $N =$ wielkość oryginalnego zbioru)

ad 2) W przypadku drzew przycinanie nie jest konieczne, bo i tak podniej średniaczą.

N elementów $\{1, 2, \dots, N\}$

$X_i = \begin{cases} 1 & \text{, jeśli } i \text{ zostanie wybrane choć raz} \\ 0 & \text{, -1- nie zostanie wybrane ani razu} \end{cases}$ $\hookrightarrow N$ losowań

$$P(X_i = 0) = \left(1 - \frac{1}{N}\right)^N \quad E X_i = 1 \cdot P(X_i = 1) + 0 \cdot P(X_i = 0) = 1 - \left(1 - \frac{1}{N}\right)^N$$

$$E(\text{liczba rzeczy wybranych} \text{ w } N \text{ losowaniach}) = E(X_1 + \dots + X_N) = E(X_1) + \dots + E(X_N) =$$

$$= N \left(1 - \underbrace{\left(1 - \frac{1}{N}\right)^N}_{\downarrow \frac{1}{e}}\right) \approx \underbrace{N}_{\text{dla dużych } N} \left(1 - \frac{1}{e}\right) \approx 0.632$$

Zadanie 3: - zrealizuj dane (np. Breast Cancer)
Titanic

do 97

• zobacz, jak działają: drzewo, ... z przycinaniem, bagging, random forest
↑
(crosscut)

Boosting (dla regresji)

N obserwacji
próbek x_1, \dots, x_N
 y_1, \dots, y_N




parametry: B - liczba drzew

λ - parametr $\in \mathbb{R}$ $\lambda \cdot B > 1$
długość kroku

d - liczba podziałów w drzewie ($d+1 =$ liczba liści)

$$\hat{f}^{(b)}(x) = \sum_{j=1}^{d+1} c_j \mathbb{1}_{R_j}(x)$$

1) Bierny $\hat{f}(x) = 0$; $r_i = y_i$ dla $i=1, \dots, N$



2) dla $b=1, 2, \dots, B$:

(a) tworzymy drzewo $\hat{f}^{(b)}$ z $d+1$ liśćmi dopasowując je do danych $(x_i, r_i)_{i=1}^N$

(b) aktualizujemy \hat{f} i r :

$$\text{nowe } \hat{f}(x) = (\text{stare } \hat{f}(x)) + \lambda \cdot \hat{f}^{(b)}(x)$$

$$\text{nowe } r_i = (\text{stare } r_i) - \lambda \hat{f}^{(b)}(x_i)$$

$$x_1 \rightarrow y_1 = 3.5 \stackrel{\lambda=0.1}{=} r_1 \quad \hat{f}^{(1)}(x_1) = 3.2$$

$$\hat{f}(x_1) = 0 + 0.1 \cdot 3.2 = 0.32$$

$$\text{nowe } r_1 = 3.5 - 0.32 = 3.18$$

$$\hat{f}(x) = \lambda (\hat{f}^{(1)}(x) + \dots + \hat{f}^{(B)}(x))$$

niezmienik: $\hat{f}(x) + r_i = y_i$

Brakujące dane: Mamy:

• pomięci rekordy, w których są brakujące dane

• skutecznie uzupełniać brakujące dane

1 2

0.6 K
0.4 m

(?, 173,)

pełni wzrost

• traktować braki jako specjalne kategorie

• znaleźć problem na ukamkowane problem (Ch. 5 do teraz)

pełni!
K ↙ ↓ M
0.6 0.4

wzrost < 175?
/ \

• można użyć wszystkich algorytmów

tworzenia drzew decyzyjnych bezpośrednio

do drzew z brakami (Ch. 5)

(tak wie w scikit)

Ross Quinlan

Dane nierównoważone

Np. dwie klasy o bardzo różnej liczności

np. 98% osób zdrowych A -
2% -ci chorzy B +

można więc postąpić do zwiększenia liczności mniejszej klasy




Tabela pomyłek (Confusion matrix)

klasyfikacja binarna

klasyfikacja / rzeczywista	-	+
-	3125	421
+	35	2235

liczba obserwacji nie zdrowy

$$421 + 35$$

$$\frac{421 + 35}{421 + 35 + 3125 + 2235}$$